BAB I
PENDAHULUAN

1.1 Latar Belakang

Pada fasilitas perawatan, informasi mengenai keberadaan staf di dalam gedung tidak hanya berguna untuk mengetahui posisi seseorang, tetapi juga untuk memantau pendampingan staf kepada pasien dan memahami beban kerja perawatan (Garcia dan Inoue, 2024). Informasi tersebut umumnya dibutuhkan pada tingkat ruangan, misalnya apakah seorang staf sedang berada di kamar pasien, *nurse station*, *kitchen*, atau *cafeteria*, karena satuan itulah yang bermakna bagi pencatatan aktivitas perawatan. Kebutuhan ini menjadikan *indoor localization* tingkat ruangan sebagai salah satu komponen pendukung layanan kesehatan berbasis *Internet of Things* (IoT).

Penentuan lokasi di dalam gedung tidak dapat mengandalkan *Global Positioning System* (GPS) karena sinyal satelit melemah atau terhalang oleh struktur bangunan (Skýpalová dkk., 2025). Sebagai alternatif, berbagai teknologi nirkabel dimanfaatkan di dalam ruangan, salah satunya *Bluetooth Low Energy* (BLE). Teknologi ini banyak digunakan karena konsumsi dayanya rendah, perangkat *beacon*-nya relatif murah dan mudah dipasang, serta sinyalnya dapat dibaca oleh perangkat bergerak yang umum digunakan (Bencak dkk., 2022). Pada pendekatan *fingerprinting*, nilai *Received Signal Strength Indicator* (RSSI) dari sejumlah *beacon* disusun menjadi pola sinyal, kemudian pola tersebut dipetakan ke label lokasi yang telah diketahui (Bouse dkk., 2024; Zholamanov dkk., 2025). Apabila lokasi dinyatakan sebagai kelas ruangan, permasalahan *indoor localization* dapat dirumuskan sebagai klasifikasi multikelas.

Data RSSI pada lingkungan nyata tidak stabil. Kekuatan sinyal yang diterima dipengaruhi oleh *multipath propagation*, redaman oleh dinding dan peralatan, kondisi *non-line-of-sight*, serta penyerapan oleh tubuh manusia yang terus bergerak (Maduranga dkk., 2024). Selain berfluktuasi, sinyal juga tidak selalu terdeteksi. Sebuah *beacon* dapat hilang dari pengamatan pada interval waktu

tertentu sehingga *fingerprint* yang terbentuk menjadi tidak lengkap. Kedua kondisi

ini, yaitu *noisy* RSSI dan *sparse signal*, menyulitkan model dalam membedakan ruangan yang letaknya berdekatan dan memiliki pola sinyal yang mirip.

Persoalan berikutnya berasal dari distribusi data. Pada lingkungan operasional, area yang sering dikunjungi menghasilkan jauh lebih banyak sampel dibandingkan ruangan yang jarang dimasuki. Ketidakseimbangan kelas (*class imbalance*) seperti ini mendorong model mengutamakan kelas mayoritas, sehingga nilai *accuracy* yang tinggi dapat menutupi kegagalan model pada kelas minoritas (Yang dkk., 2024). Pada data penelitian ini, kelas minoritas justru didominasi oleh ruang bernomor seperti kamar pasien, yaitu lokasi yang penting dalam pencatatan pendampingan perawatan. Oleh karena itu, evaluasi model perlu menggunakan metrik yang memberikan bobot setara pada setiap kelas, seperti *Macro F1-score*, dan dilengkapi dengan analisis per kelas.

Penelitian ini menggunakan *dataset* dari tantangan pengenalan lokasi pada fasilitas perawatan (*location recognition challenge in care facilities*) yang diselenggarakan bersama *International Conference on Activity and Behavior Computing* (ABC) 2026 (Garcia dkk., 2026), selanjutnya disebut *dataset* ABC 2026. Data dikumpulkan di lantai 5 sebuah *nursing care facility* pada 10–13 April 2023 menggunakan 25 *stationary beacon* BLE, sedangkan nilai RSSI direkam melalui aplikasi pada perangkat bergerak yang dibawa staf perawat selama jam kerja. Pengolahan awal terhadap data tersebut memperlihatkan persoalan sinyal dan distribusi kelas secara nyata. Sebanyak 1.673.395 observasi BLE yang dikelompokkan ke dalam *temporal window* 5 detik menghasilkan 9.012 *fingerprint*, dengan 86,04% sel fitur kosong sebelum imputasi. Ringkasan karakteristik *dataset* disajikan pada Tabel 1.1.

Tabel 1.1 Karakteristik *Dataset* ABC 2026

No.	Karakteristik	Nilai
1	Periode pengumpulan data	10–13 April 2023
2	Lokasi pengumpulan data	Lantai 5 *nursing care facility*
3	Jumlah *stationary beacon* BLE	25 *beacon*
4	Jumlah observasi BLE	1.673.395 observasi
5	Ukuran *temporal window*	5 detik
6	Jumlah *fingerprint*	9.012 *fingerprint*
7	Tingkat sparsitas sinyal	86,04%
8	Catatan label lantai 5	451 catatan (23 lokasi)
9	*Fingerprint* berlabel setelah *temporal alignment*	601 sampel
10	Jumlah kelas lokasi	21 kelas
11	Rasio ketidakseimbangan kelas	51,33:1

Setelah diselaraskan dengan label lokasi, hanya 601 *fingerprint* yang memperoleh label dan sampel tersebut tersebar pada 21 kelas. Dua lokasi lain pada catatan label tidak memperoleh pasangan *fingerprint* dalam toleransi waktu yang ditetapkan. Distribusi sampelnya sangat timpang. Kelas *cafeteria* memiliki 154 sampel dan *nurse station* 149 sampel, sedangkan beberapa ruang bernomor hanya memiliki tiga sampel, sehingga rasio kelas terbesar terhadap kelas terkecil mencapai 51,33:1. Distribusi tersebut ditunjukkan pada Tabel 1.2.

Tabel 1.2 Distribusi Kelas Lokasi pada Data Berlabel

No.	Label Lokasi	Jumlah Sampel	Persentase	Kategori
1	*cafeteria*	154	25,62%	Mayoritas
2	*nurse station*	149	24,79%	Mayoritas
3	*kitchen*	97	16,14%	Mayoritas
4	*hallway*	59	9,82%	Menengah
5	*cleaning*	44	7,32%	Menengah
6	11 ruang bernomor lainnya	81 (5–17 per kelas)	13,48%	Minoritas
7	502 dan 515	4 per kelas	0,67% per kelas	Minoritas
8	501, 503, dan 516	3 per kelas	0,50% per kelas	Minoritas
	Jumlah	**601**	**100,00%**	

Penelitian pada lingkungan dengan karakteristik serupa menunjukkan bahwa persoalan tersebut belum sepenuhnya terselesaikan. Garcia dkk. (2024) memanfaatkan kemiripan pola sinyal antarruangan untuk melakukan *relabeling* data *beacon* pada fasilitas perawatan dan memperoleh *accuracy* 74% menggunakan *Random Forest*, atau 5% lebih tinggi dibandingkan penggunaan data asli. Garcia dan Inoue (2024) mengembangkan pendekatan *relabeling* tersebut dan melaporkan *F1-score* kelas minoritas yang lebih tinggi dibandingkan augmentasi dengan *random sampling*, SMOTE, dan ADASYN. Okuda dkk. (2024a, 2024b) juga menunjukkan bahwa catatan aktivitas pada fasilitas perawatan rentan terhadap entri yang hilang dan kesalahan pencatatan waktu. Temuan-temuan tersebut menegaskan dua hal. Pertama, kualitas dan distribusi data merupakan persoalan utama pada lingkungan perawatan, bukan sekadar pilihan algoritma. Kedua, *oversampling* sintetis tidak otomatis memberikan hasil terbaik, sehingga penggunaannya perlu disertai mekanisme pembersihan sampel dan dievaluasi secara hati-hati.

Di sisi lain, model berbasis pohon keputusan dan *gradient boosting*, seperti LightGBM dan CatBoost, telah dikembangkan untuk mempelajari hubungan *nonlinear* antarfitur secara efisien (Ke dkk., 2017; Prokhorenkova dkk., 2018), sedangkan teknik *oversampling* banyak digunakan untuk menangani klasifikasi multikelas yang tidak seimbang (Yang dkk., 2024). Namun, berdasarkan

penelusuran pustaka pada Bab II, komponen-komponen tersebut umumnya dibahas secara terpisah. Evaluasi yang menggabungkan representasi sinyal berbasis waktu, seleksi fitur, penyeimbangan kelas, dan penggabungan model heterogen dalam satu alur pada data BLE fasilitas perawatan yang *sparse* dan tidak seimbang masih terbatas.

Berdasarkan permasalahan tersebut, penelitian ini menerapkan pendekatan *imbalance-aware stacking ensemble* yang menangani persoalan pada tiga tingkat. Pada tingkat representasi, pembacaan RSSI diringkas dalam *temporal window* 5 detik menggunakan *mean*, *standard deviation*, median, dan *count* untuk setiap *beacon*, sehingga *fingerprint* tidak hanya memuat kekuatan sinyal, tetapi juga variasi dan ketersediaan pengamatannya. *Fingerprint* kemudian diimputasi, distandardisasi, dan diseleksi menggunakan *Mutual Information* untuk mempertahankan fitur yang paling informatif terhadap label lokasi. Pada tingkat distribusi data, SMOTE-Tomek diterapkan pada data latih awal setelah data *holdout* dipisahkan untuk menambah sampel kelas minoritas sekaligus membersihkan pasangan sampel yang tumpang tindih pada batas kelas. Pada tingkat model, *Logistic Regression*, *Random Forest*, LightGBM, dan CatBoost digabungkan melalui *stacking* dengan *Logistic Regression* sebagai *meta-learner*. *Soft voting* dengan anggota yang sama digunakan sebagai pembanding agar kontribusi *meta-learner* dapat dipisahkan dari efek penggabungan model semata.

Kerangka awal pendekatan ini telah dikembangkan dalam naskah Pujianto dkk. (2026) untuk tantangan ABC 2026 dengan menggunakan SMOTE dan tiga *base learner*, yaitu *Random Forest*, *Logistic Regression*, dan CatBoost, yang digabungkan melalui *meta-learner* dan agregasi *voting* pada tingkat akhir. Skripsi ini memperluas kerangka tersebut melalui tiga perubahan. SMOTE diganti dengan SMOTE-Tomek agar sampel yang tumpang tindih pada batas kelas ikut dibersihkan, LightGBM ditambahkan sebagai *base learner* keempat, dan *soft voting* dipisahkan menjadi model pembanding. Selain *accuracy* dan *Macro F1-score*, kinerja model juga dianalisis melalui *F1-score* per kelas dan *confusion matrix* untuk melihat lokasi yang paling sulit dibedakan.

Berdasarkan uraian tersebut, penelitian ini berjudul "Penerapan *Imbalance-*

Aware Stacking Ensemble untuk Klasifikasi Lokasi *Indoor* Berbasis BLE RSSI pada Lingkungan Kesehatan".

1.2 Rumusan Masalah

Berdasarkan latar belakang yang telah diuraikan, rumusan masalah dalam penelitian ini adalah sebagai berikut.

1. Bagaimana karakteristik data BLE RSSI pada *dataset* ABC 2026, khususnya tingkat sparsitas sinyal, fluktuasi RSSI, dan ketidakseimbangan kelas, serta implikasinya terhadap klasifikasi lokasi tingkat ruangan?
2. Bagaimana penerapan *temporal fingerprinting* 5 detik, imputasi, standardisasi, seleksi fitur berbasis *Mutual Information*, dan SMOTE-Tomek dalam membentuk data klasifikasi lokasi *indoor* berbasis BLE RSSI?
3. Bagaimana kinerja *imbalance-aware stacking ensemble* dengan *Logistic Regression*, *Random Forest*, LightGBM, dan CatBoost sebagai *base learner* serta *Logistic Regression* sebagai *meta-learner* dibandingkan dengan model individual dan *soft voting ensemble* berdasarkan *accuracy* dan *Macro F1-score*, serta bagaimana kinerja per kelasnya berdasarkan *F1-score* per kelas dan *confusion matrix*?

1.3 Tujuan Penelitian

Berdasarkan rumusan masalah tersebut, tujuan penelitian ini adalah sebagai berikut.

1. Menganalisis karakteristik data BLE RSSI pada *dataset* ABC 2026, khususnya tingkat sparsitas sinyal, fluktuasi RSSI, dan ketidakseimbangan kelas, serta implikasinya terhadap klasifikasi lokasi tingkat ruangan.
2. Menerapkan *temporal fingerprinting* 5 detik, imputasi, standardisasi, seleksi fitur berbasis *Mutual Information*, dan SMOTE-Tomek pada data latih awal untuk membentuk data klasifikasi lokasi *indoor* berbasis BLE RSSI.
3. Membangun *imbalance-aware stacking ensemble* dengan *Logistic Regression*, *Random Forest*, LightGBM, dan CatBoost sebagai *base learner* serta *Logistic Regression* sebagai *meta-learner*, kemudian membandingkan kinerjanya dengan model individual dan *soft voting ensemble* berdasarkan *accuracy* dan *Macro F1-score*, serta menganalisis kinerja per kelasnya

berdasarkan *F1-score* per kelas dan *confusion matrix*.

1.4 Manfaat Penelitian

Penelitian ini diharapkan memberikan manfaat sebagai berikut.

1. Manfaat akademis
   a. Memberikan bukti empiris mengenai penerapan gabungan representasi sinyal berbasis waktu, seleksi fitur, penyeimbangan kelas, dan *stacking ensemble* pada klasifikasi lokasi BLE RSSI yang *sparse* dan tidak seimbang.
   b. Menjadi rujukan bagi penelitian lanjutan yang menggunakan data BLE dari fasilitas perawatan, termasuk sebagai pembanding bagi pendekatan *relabeling* yang telah dilaporkan sebelumnya.
2. Manfaat praktis
   a. Menyediakan alur pengolahan data BLE dari rekaman mentah hingga *fingerprint* tingkat ruangan yang dapat digunakan kembali pada data sejenis.
   b. Memberikan informasi mengenai lokasi yang paling sulit dibedakan sebagai bahan pertimbangan penempatan *beacon* dan pengumpulan data tambahan.
   c. Menjadi dasar awal pengembangan sistem pemantauan lokasi staf pada fasilitas perawatan berbasis BLE.

1.5 Ruang Lingkup dan Batasan Penelitian

Agar penelitian lebih terarah, ruang lingkup dan batasan penelitian ditetapkan sebagai berikut.

1. Data yang digunakan adalah *dataset* sekunder ABC 2026 yang direkam di lantai 5 *nursing care facility* pada 10–13 April 2023. Penelitian tidak mencakup pengambilan data, pemasangan *beacon*, maupun pengujian langsung di fasilitas kesehatan.
2. Masukan model dibatasi pada nilai RSSI dari 25 *stationary beacon* BLE dan label lokasi. Data sensor lain yang tersedia pada sumber *dataset*, seperti akselerometer, tidak digunakan.
3. Label lokasi dibatasi pada lantai 5. Kelas yang dianalisis adalah lokasi yang

memperoleh pasangan *fingerprint* dalam toleransi waktu 5 detik, yaitu sebanyak 21 kelas.

4. Klasifikasi dilakukan pada tingkat ruangan (*room-level classification*) dan tidak ditujukan untuk memperkirakan koordinat posisi.
5. Representasi sinyal dibentuk menggunakan *temporal window* 5 detik dengan empat statistik untuk setiap *beacon*, yaitu *mean*, *standard deviation*, median, dan *count*.
6. Seleksi fitur hanya menggunakan *Mutual Information*. Penanganan ketidakseimbangan kelas pada tingkat data hanya menggunakan SMOTE-Tomek yang diterapkan pada data latih awal, sedangkan pada tingkat model digunakan pembobotan kelas (*class_weight = balanced*) yang tersedia pada setiap algoritma. Data *holdout* dipisahkan sebelum *resampling*.
7. Model yang dibandingkan adalah *Logistic Regression*, *Random Forest*, LightGBM, CatBoost, *stacking ensemble* dengan *Logistic Regression* sebagai *meta-learner*, dan *soft voting ensemble*. Hiperparameter setiap model ditetapkan tetap tanpa proses pencarian hiperparameter, dan pendekatan *deep learning* tidak termasuk dalam cakupan penelitian.
8. Kinerja model diukur menggunakan *accuracy* dan *Macro F1-score* pada data *validation* yang dibentuk dari data latih hasil SMOTE-Tomek, serta dianalisis per kelas melalui *F1-score* dan *confusion matrix*. Evaluasi pada data *holdout* tidak termasuk dalam cakupan penelitian ini.
9. Implementasi dilakukan menggunakan bahasa pemrograman Python pada Google Colab. Penelitian tidak mencakup implementasi sistem secara *real-time*.